

平成27年度修士論文

単ードップラーライダーのための パラメトリック風速ベクトル推定法

学 籍 番 号 1432058

氏 名 増尾 崇幸

知能機械工学専攻 電子制御システムコース

指 導 教 員 桐本 哲郎 教授

副指導教員 稲葉 敬之 教授

提 出 日 平成28年 2月 29日

概要

気象レーダは、大気中の雲状の粒子や降水粒子からの後方散乱波を観測することにより、降水分布や強度を推定する。近年の気象レーダは受信信号の周波数偏移量を抽出して、降水粒子等の移動速度を計測し、広範囲な観測領域の風向・風速を2次元あるいは3次的に高分解能に推定できる。また、ドップラーレーダは雲粒子や降水粒子からの散乱波を利用するため、雨天時の運用にその効力が大きい。一方、晴天時の観測には、波長数 μm のレーザ光を送受信し、大気中の微粒子(エアロゾル)からのミー散乱を利用するドップラーライダーが、例えば、空港周辺の気象監視等への目的として、注目されている。航空機の安全な航行を確保するためには、離着陸時の風向・風速の変化を実時間で捉える必要がある。二次元の風速ベクトル場を決定するためには、原理的には複数のドップラーライダーを用いて複数方向から同一領域を観測する必要がある。異なる方向からの計測量を得るためには、適当な距離を置いて設置された複数のドップラーライダーを時間的に同期させた設置運用が必要であり、システムの規模やコストが大きくなる課題を抱えており、単一のドップラライダーによる2次元風速ベクトル場推定法が要求されている。

上記を実現する手法として、VAD(VAD:Velocity Azimuth Display)法及び、VVP(VVP:Velocity Volume Processing)法等がある。VAD法は、風の局所的な一様性を仮定し、近接する観測セルの計測量の相関から、風向・風速を求める。しかし、同手法は乱気流等のように、相関領域内の風速ベクトルの変化が大きい場合では誤差が無視できない。一方、VVP法では、局所的な観測領域に風の線形変化を仮定することで、風速ベクトルの推定が可能である。しかし、竜巻のような局所的な変化の非線形性が強い場合においては、VAD法と同様に大きな推定誤差を生じる。上記の問題に対し、相関領域の自動最適化機能を持つ拡張VAD法を以前に提案した。拡張VAD法ではVAD法やVVP法と比べ推定精度の向上が確認されたが、乱気流の推定精度が十分確保できないという問題があった。また、これら手法は局所的な風の推定を目的としているため、乱気流の認識を行うためには、別途認識手法を用意する必要がある。そこで、本研究では局所的に風向風速を推定すると共に、大局的に乱気流モデルを認識できるパラメトリック風速ベクトル推定法を提案する。本手法は、乱気流を記述する数理モデルパラメータを評価関数の最適化により推定すると共に、評価関数値の比較から観測領域における乱気流モデルを決定する。風速ベクトルは、決定された乱気流モデルおよびパラメータを用いて再構成することで推定される。パラメータの推定には、多峰性を示す評価関数の

最適化を必要とするため，群知能の一種である粒子群最適化 (PSO:Particle Swarm Optimization) を用いて探索精度の向上を図る．数値計算に基づく性能評価により，本研究の有効性を確認する．

目次

1	序論	1
1.1	研究背景	1
1.2	目的	3
2	従来の風速ベクトル場推定法	4
2.1	VAD 法による風速推定	4
2.2	VVP 法による風速推定	6
2.3	拡張 VAD 法による風速推定	7
3	従来法の性能評価	9
3.1	システムモデル	9
3.2	乱気流の数値モデル	9
3.3	各手法の性能評価	12
3.3.1	VAD 法の性能評価	12
3.3.2	VVP 法の性能評価	14
3.3.3	拡張 VAD 法の性能評価	14
3.4	推定精度の定量評価	20
4	パラメトリック風速ベクトル推定法	21
4.1	勾配法を用いた各乱気流パラメータの推定	21
4.2	粒子群最適化 (PSO) を用いた乱気流パラメータの推定	23
4.3	相関長無限大のパラメトリック推定	29

5	提案法の性能評価	33
5.1	評価方法	33
5.2	風速ベクトルの推定精度	34
5.3	気流モデルの認識精度	42
6	結論	49
	謝辞	50
7	付録	51
.0.1	信頼領域法	51
.0.2	粒子群最適化 (PSO)	52
.0.3	キャニー法	53
	参考文献	55

第 1 章

序論

1.1 研究背景

気象状況の把握や予測には、電波や光を用いた宇宙および地上からのリモートセンシングが有用である。気象庁から提供される気象衛星ひまわりで観測された雲画像や、気象レーダで観測される降水強度分布等は、代表的な例である。気象レーダでは、降水粒子の移動に伴うドップラー効果を利用した風向・風速（風速ベクトル）の観測が可能である。米国では1980年代から、ドップラーレーダを空港周辺に発生する低層ウィンドシヤー（高度500m以下に発生する急激な風速風向の変化）の検出に用いる機運が高まった。FAA(FAA:Federal Aviation Administration)はCバンドの低層ウィンドシヤー検出用のドップラーレーダTDWR(TDWR:Terminal Doppler Weather Radar)[1]、[2]を1990年代から米国の主要空港に展開してきた。日本でも関西空港を始めとして、空港気象ドップラーレーダDRAW(DRAW:Doppler Radar for Airport Weather)の運用が1995年より始まっている[3]。航空機は大気と機体の相対的な速度差によって揚力を得ているため、特に機体の速度が低く不安定な離着陸時には、急激な風況変化が航空機の重大な事故に繋がりがねない。過去、高度1600ft(約500m)以下で発生する低層ウィンドシヤーが原因と見られる墜落事故が、数多く報告されている[4]。これら現象を素早く検出することが安全な航行に不可欠である。ドップラーレーダによる風速ベクトルの推定は、降水粒子が存在する領域において効果が大きく、晴天時の観測は困難となる。晴天時の空港気象を監視する方法として、レーザ光を送受信するドップラーライダーを用いる方法が提案されて

いる．ライダは波長数 μm のレーザ光を送信し，大気中を漂う微粒子（エアロゾル）からのミー散乱を受信することでラディアル速度を計測する．一般に風速ベクトルの計測には，複数台のドップラーライダを用いた観測が必要であるが，コスト増および装置の大規模化を避けるため，単一のドップラーライダを用いて観測で風速ベクトルを推定する方法がいくつか考案されている．VAD(VAD:Velocity Azimuth Display) 法 [5][6] は，その代表的な方法であり，風速ベクトルの局所的な一様性を仮定することで風速ベクトルを推定する．しかし，従来の VAD 法に基づく風速ベクトル推定法では，局所的に一様な風を仮定するために乱気流の推定精度が著しく劣化する問題がある．その結果，VAD 法では，竜巻のような風速ベクトル変化の大きな場合，推定精度の劣化が顕著となる課題を抱えていた．一方，VVP(VVP:Velocity Volume Processing) 法 [7] は，局所的な観測領域に風速ベクトルの線形変化を仮定する推定法である．しかし，VAD 法と同等に急激な風速ベクトル変化が生じる乱気流を観測する場合，推定精度の保持が困難である問題がある．同問題に対し，筆者は関連領域を風速場に応じて自動最適化機能を持つ拡張 VAD 法を考案しこれにより風向・風速の推定精度が向上することを明らかにした [8]．しかしながら，実用化するためにはさらに推定精度を向上させることが必要であった．単一のドップラーライダ（レーダ）を用いた風速ベクトルの推定法においては，依然として乱気流の高精度推定に課題を残す [9]．

1.2 目的

本研究の目的は、従来法の課題を克服し、ドップラーライダからの観測量を用いて高精度に風速ベクトル推定すると共に、観測領域内の発生气流を認識する手法の構築である。また、従来の局所的に一律な風を仮定する手法では、大局的に風速ベクトルを俯瞰して、場の乱気流パターンを認識することが困難である。そこで観測されるラディアル速度分布より、風速ベクトル場を記述するモデル決定及びパラメータを推定し、これの再構成を行うパラメトリック風速ベクトル推定法を提案する。しかし、各風速ベクトル場のパラメータ推定に用いる評価関数の形状は多峰性であるため、一般的な最適化手法である評価関数のスロープを利用した勾配法ではパラメータ推定精度に大きな誤差を生じる。

同問題に対し、本研究では群知能の一種である粒子群最適化 (PSO: Particle Swarm Optimization) [10][11] を用いることにより、風速ベクトル場パラメータを推定し、観測領域における風速ベクトルの推定と乱気流モデルを自動認識する手法を提案する。

第 2 章

従来の風速ベクトル場推定法

本章では，単一のライダーを用いた風速ベクトル場推定法として，VAD 法，VVP 法および拡張 VAD 法に基づく風速ベクトルの推定法について説明する．

2.1 VAD 法による風速推定

VAD 法は同レンジ距離の観測ラディアル速度分布から風速と風向を推定する手法である．図 2.1 において，地球の湾曲効果とエアゾルの落下速度を無視でき




図 2.1: 2 次元問題における VAD 法の観測座標系

る場合，ラディアル速度は次式で表現される．

$$v_r(r, \varphi) = \frac{1}{2}r \left(\frac{\partial u}{\partial x} + \frac{\partial v}{\partial y} \right) + v_0 \cos \varphi + u_0 \sin \varphi \\ + \frac{1}{2}r \left(\frac{\partial v}{\partial y} - \frac{\partial u}{\partial x} \right) \cos 2\varphi + \frac{1}{2}r \left(\frac{\partial v}{\partial x} + \frac{\partial u}{\partial y} \right) \sin 2\varphi, \quad (2.1)$$

但し, (u, v) は風速ベクトル v_h の x, y 成分, (u_0, v_0) は相関領域の中心における風速ベクトル成分である. 同領域に, 風向・風速が一定の一樣風を仮定すると, ラディアル速度分布は余弦曲線を用いて次式で表される.

$$v_r(v_h(\mathbf{r}_i), \theta(\mathbf{r}_i)) = v_h \cos(\theta - \varphi) \quad (2.2)$$

但し, v_h は風速, θ は風向, φ は観測方位角である. ドップラー速度はレーザビームの進行方向の逆向きを正とする. 風速ベクトルは観測ラディアル速度分布曲線 (2.2) と観測ラディアル速度から, 最小二乗的に最適化問題を解くことにより次式で求められる.

$$\left(\hat{v}_h(\mathbf{r}_i), \hat{\theta}(\mathbf{r}_i) \right) = \arg \min_{v_h(\mathbf{r}_i), \theta(\mathbf{r}_i)} \sum_{\mathbf{r}_i \in \Omega_i} \{v_r(v_h(\mathbf{r}_i), \theta(\mathbf{r}_i)) - v_{r, \text{obs}}(\mathbf{r}_i)\}^2 \quad (2.3)$$

但し, \mathbf{r}_i は観測セル位置, Ω_i は一樣風を仮定する相関領域, $v_{r, \text{obs}}(\mathbf{r}_i)$ は観測ラディアル速度である. 一般に, ウィンドプロファイラ等で用いられる高高度風速ベクトル推定における VAD 法は, 同レンジ距離の観測セルに対し方位角 360° の走査を行う. VAD 法の特徴は, この相関領域で一樣な風が吹いていると仮定することにある. しかし, 観測領域に乱気流等が分布する場合, 風速ベクトルの変化が大きく, 同領域内で風速ベクトルが一定の一樣風と仮定するには限界がある. そのため仮定との誤差を減らし VAD 法を適用させるためには, 図 2.2(a) に示すように局所的な観測領域に対し一樣風を仮定し, 相関領域を限定するのが現実的である. 詳しい相関領域の抽出については次章の性能評価で述べる.

2.2 VVP 法による風速推定

VVP 法は相関領域内のラディアル速度分布から直接風向・風速を推定する手法である。VAD 法では風向・風速が一定の一様風を仮定したのに対し、同手法は風速ベクトルの線形変化を仮定する。相関領域のある一点 (x, y) の風速ベクトル $\mathbf{v}(x, y)$ は、中心座標を (x_0, y_0) の風速ベクトルに対し、テイラー級数による一次近似を用いて次式で表現できる。

$$\mathbf{v}(x, y) \simeq \mathbf{v}(x_0, y_0) + \frac{\partial \mathbf{v}}{\partial x} (x - x_0) + \frac{\partial \mathbf{v}}{\partial y} (y - y_0) \quad (2.4)$$

このとき、ラディアル速度は座標系に関する行列 \mathbf{P}_m と、風速ベクトルに関する行列 \mathbf{K}_m を用いて次式で与えられる。

$$v_r = \mathbf{v} \cdot (\mathbf{i}_x \sin \varphi + \mathbf{i}_y \cos \varphi) = \mathbf{P}_m \mathbf{K}_m \quad (2.5)$$

$$\text{但し, } \mathbf{P}_m = \begin{bmatrix} \sin \varphi \\ \cos \varphi \\ \sin \varphi (r \sin \varphi - x_0) \\ \cos \varphi (r \cos \varphi - y_0) \\ r \sin \varphi \cos \varphi \end{bmatrix}^T, \mathbf{K}_m = \left(u_0', v_0', \frac{\partial u}{\partial x}, \frac{\partial v}{\partial y}, \left(\frac{\partial u}{\partial y} + \frac{\partial v}{\partial x} \right) \right)^T \text{ である.}$$

m は行列 \mathbf{K}_m のランク数、 $\mathbf{i}_x, \mathbf{i}_y$ は、 x と y それぞれの方向の単位ベクトルである。 u_0', v_0' は $u_0' = u_0 - \frac{\partial u}{\partial y} y_0$ and $v_0' = v_0 - \frac{\partial v}{\partial x} x_0$ で表現され、修正風速成分と呼ばれる。一般に、1 回の観測から得られるデータ数 n は $n \gg m$ を満たすため、観測ラディアル速度からなるベクトル \mathbf{v}_{rn} は、それらに対応する $n \times m$ 行列である \mathbf{P}_{nm} を用いて次式で表される。

$$\mathbf{v}_{rn} = \mathbf{P}_{nm} \mathbf{K}_m \quad (2.6)$$

観測方程式である 2.6 に対する最小二乗解は、

$$\mathbf{K}_m = (\mathbf{P}_{nm}^T \mathbf{P}_{nm})^{-1} (\mathbf{P}_{nm}^T \mathbf{v}_{rn}) \quad (2.7)$$

によって求められ，各風速成分が算出される．但し， u_0' ， v_0' は風のローテーション成分を含むため，同成分の項が大きくなる乱気流の風速ベクトル推定においては，推定精度の劣化が生じる．また，線形変化を一次微分を用いて近似する同手法は，ゆらぎ等の計測誤差に敏感であることにも留意する必要がある．図 2.2(b) に同手法の相関領域を示す．先述の通り，相関領域から得られるデータ数は $n \gg m$ を満たすよう，同領域を決定する必要がある．詳しい相関領域の抽出については次章の性能評価で述べる．




図 2.2: VAD 法，VVP 法における相関領域

2.3 拡張 VAD 法による風速推定

VAD 法では相関領域内に一様風を仮定し，観測されるラディアル速度分布を用いて風速ベクトルの推定を行う．一様風のように風速ベクトルの変化が少なく，VAD

法の仮定が合理的である場合では，同領域を拡大して VAD 法の推定精度を向上させることができる．一方，乱気流下では，同領域を縮小し風速ベクトル変化の影響を低減させた VAD 法の適用が望ましい．そこで，本手法では相関領域を風速ベクトル場に応じて適応的に変化させる機能を VAD 法に導入し，乱気流の推定精度向上させる．本稿ではこれを拡張 VAD 法と定義する．評価関数は次式で表される．

$$\left(\hat{v}_h(\mathbf{r}_i), \hat{\theta}(\mathbf{r}_i), \hat{\sigma}(\mathbf{r}_i) \right) = \arg \min_{v_h(\mathbf{r}_i), \theta(\mathbf{r}_i), \sigma(\mathbf{r}_i)} \frac{\sum_{\mathbf{r}_j \in \Omega_i} e^{-\frac{|\mathbf{r}_i - \mathbf{r}_j|^2}{2(\sigma(\mathbf{r}_i))^2}} (f(v_h(\mathbf{r}_i), \theta(\mathbf{r}_i)) - v_r(\mathbf{r}_j))^2}{\sum_{\mathbf{r}_j \in \Omega_i} e^{-\frac{|\mathbf{r}_i - \mathbf{r}_j|^2}{2(\sigma(\mathbf{r}_i))^2}}} \quad (2.8)$$

但し， $v_h(\mathbf{r}_i)$ および $\theta(\mathbf{r}_i)$ は風速と風向， $\sigma(\mathbf{r}_i)$ は相関長， Ω_i は相関領域， v_r は観測ラディアル速度， $f(v_h(\mathbf{r}_i), \theta(\mathbf{r}_i))$ は風速ベクトルが一様と仮定した場合のラディアル速度分布である．距離による重み付け最小二乗近似を適用させることにより，観測セル \mathbf{r}_i に近いセルの観測値の寄与は高く，基準観測セルから離れた観測量の寄与を低くする効果が期待できる．ここでは隣接する観測セルに相関の高い風速ベクトルが分布することを想定している．図 2.3 に同手法の相関領域の適応的变化を示す．




図 2.3: 拡張 VAD 法における相関領域の適応的变化

第 3 章

従来法の性能評価

本章では，数値計算のシステムモデルと乱気流の数値モデル，VAD 法および拡張 VAD 法に基づく風速ベクトルの推定結果および定量評価結果を示す．

3.1 システムモデル

数値計算のシステムモデルを図 3.1 に示す．モノスタティックライダを想定し，送受信アンテナを $x = 0, y = 0$ に設置する．レンジ方向の距離分解能は 150m，方位角分解能は 6° とする．観測セル数はレンジ方向に 20 個，アジマス方向に 11 個とし， $-30^\circ \leq \varphi \leq 30^\circ$ の範囲を走査させる．観測ラディアル速度計測範囲は $-30\text{m/s} \leq v_r \leq 30\text{m/s}$ とする．ラディアル速度はアンテナから見て向かい風を正，追い風を負とする．

3.2 乱気流の数値モデル

ここでの数値計算には，一様風，竜巻，マイクロバースト，ガストフロントの 4 つの乱気流モデルを考える．各乱気流モデルによる風速ベクトルを図 3.2 に示す．

(1) 一様風モデル

一様風は風速，風向が一定の風速ベクトル場である．一様風モデルを記述す




図 3.1: システムモデル

るパラメーターは風速 v_h と風向 θ の 2 つである．真値パラメータは $(v_h, \theta) = (10\text{m/s}, 135^\circ)$ とする．

(2) 竜巻モデル

竜巻はランキン渦モデル [12] を用いて工学的に近似できることが一般的に知られており，風速ノルム $\|v_h\|$ の変化は次式で与えられる．

$$\|v_h\|(x, y) = \begin{cases} \frac{v_c}{r_c} d(x, y) & (d \leq r_c) \\ \frac{v_c r_c}{d(x, y)} & (d > r_c) \end{cases} \quad (3.1)$$

但し， r_c はコア半径， v_c はコア半径における速度である．竜巻の風速はコア半径で最大となる．また， d は竜巻の中心座標 (x_c, y_c) と観測セル座標 (x, y) を用いて $d(x, y) = \sqrt{(x_c - x)^2 + (y_c - y)^2}$ と表せる．本稿では，渦の回転方向を時計回りとし，風向 θ は次式で定義する．

$$\theta(x, y) = \tan^{-1} \left(\frac{x - x_c}{y - y_c} \right) + \frac{\pi}{2}. \quad (3.2)$$

竜巻モデルを記述するパラメータは中心位置 (x_c, y_c) , コア半径 r_c , コア半径速度 v_c の 4 つである . 真値パラメータは $(x_c, y_c, r_c, v_c) = (0\text{m}, 1500\text{m}, 200\text{m}, 20\text{m/s})$ とする .

(3) マイクロバーストモデル

マイクロバーストは強い下降気流が地表にぶつかることにより生じる局所的な噴出しである . マイクロバーストモデルは竜巻で用いたランキン渦モデルに類似した風速変化が観測されるが , 風向が異なる [13]. 放射状の風向 θ は次式で定義する .

$$\theta(x, y) = \tan^{-1} \left(\frac{x - x_c}{y - y_c} \right). \quad (3.3)$$

真値パラメータは $(x_c, y_c, r_c, v_c) = (0\text{m}, 1500\text{m}, 200\text{m}, 20\text{m/s})$ とする .

(4) ガストフロントモデル

ガストフロントは風と風がぶつかりあうことにより生じる上昇気流モデルである . ガストフロントモデルの風速変化は次式で与えられる .

$$\|\mathbf{v}_h\|(x, y) = \begin{cases} v \cos \left(\tan^{-1} \left(-\frac{\sigma^2}{D(x, y)^2} \right) \right) & ((x, y) \in \Omega_1) \\ -v \cos \left(\tan^{-1} \left(-\frac{\sigma^2}{D(x, y)^2} \right) \right) & ((x, y) \in \Omega_2) \end{cases} \quad (3.4)$$

ここで , D は $D(x, y) = \sqrt{(x_c - x)^2 + (y_c - y)^2} - R$ で与えられる . 領域 Ω_1 と領域 Ω_2 の境界はシャーラインと呼ぶ . v は最大風速 , σ はシャーラインからの距離に応じた風速変化を与える分散である . シャーライン内外の風向 θ は次式で定義する .

$$\theta(x, y) = \begin{cases} \tan^{-1} \left(\frac{x - x_c}{y - y_c} \right) & ((x, y) \in \Omega_1) \\ \tan^{-1} \left(\frac{x - x_c}{y - y_c} \right) - \pi & ((x, y) \in \Omega_2) \end{cases} \quad (3.5)$$


ガストフロントモデルを記述するパラメータは中心位置 (x_c, y_c) , シヤーライン半径 R , 最大速度 v , 速度変化分散 σ の 5 つである . 真値パラメータは $(x_c, y_c, R, v, \sigma) = (-1500\text{m}, 3000\text{m}, 2000\text{m}, 5\text{m/s}, 140\text{m})$ とする .

図 3.2 に , 一様風 , 竜巻 , マイクロバースト , ガストフロントの風速ベクトルの真値を示す .


3.3 各手法の性能評価

3.3.1 VAD 法の性能評価


前章で触れたように , 風向・風速の推定には相関領域を限定した VAD 法の適用が望ましい . そこで曲線フィッティングに必要な最小情報量である 3 点の観測セルを含む相関領域内にて , VAD 法を適用させる . そのため , ライダ遠方の相関領域は拡大する . 基準観測セルを中心として方位角の異なる 2 点の観測セルをとり , 推定された風向・風速を基準観測セルに吹く一様風のパラメータとする . 図 3.3 に , VAD 法を用いた各乱気流モデルにおける風速ベクトルの推定結果を示す . 一様風に関しては , 精度の高い風速ベクトルの推定が可能なが分かる . 一方 , 乱気流では曲線近似に使用する観測セルを含む相関領域内で急激に風速ベクトルが変化する . 先述の通り , VAD 法は同領域内で一様な風が吹くと仮定するため , 風速ベクトルが変化する乱気流モデルでは推定結果に大きな誤差を生じていることが分かる . 特に竜巻やマイクロバーストは , 推定された風向が真値と 90° 以上の誤差を含んでいる箇所が , 渦中心および噴出し中心より遠方に多々見られる . これは , 相関領域内の乱気流のラディアル分布が , 実際に分布する風速ベクトルとは大きく異なる一様風分布に , 高い相関を示してしまうことに原因があり , 単一のライダを用いた観測では , 風向の変化によるラディアル速度の減少および , 風速の減衰によるラディアル速度の減少の区別が困難であることがわかる . このように VAD 法では , 乱気流の風速ベクトルの推定精度が著しく劣化することが問題となる .




Uniform Distribution model



Tornado model



Microburst model



Gust front model

図 3.2: 各乱気流モデルの真値風速ベクトル


3.3.2 VVP 法の性能評価

VVP 法では，観測方程式の最小二乗解を得るため，観測から得られるデータ数 n と，風速ベクトルに関する行列 K_m のランク数である m が， $n \gg m$ を満たす必要がある．そこで，基準観測セルを中心とした 5×5 の観測データを利用する相関領域を本手法に適用させる．また，VAD 法同様，ライダ遠方では相関領域が拡大する．基準観測セルが観測領域端の場合では，最小で 3×3 行列分のデータ数を用いて風速ベクトルを推定することになるが，本研究においては $m = 5$ のため逆行列演算を用いた最小二乗解が得られる．図 3.4 に，VVP 法を用いた各乱気流モデルにおける風速ベクトルの推定結果を示す．一様風では，風速ベクトル推定が高精度に行われていることが見て取れる．一方で，乱気流の推定ではモデルの判別が視覚的に行うことが難しいことがわかる．特に，竜巻モデルの渦上の風速ベクトル分布や，マイクロバーストモデルの放射状の風速ベクトル分布の確認が出来ない．これは同モデルの風速ベクトル変化が，相関領域において非常に急激かつ非線形変化であることが，推定精度の著しい劣化の原因として考えられる．また，本稿におけるシステムモデルは，観測領域を粗に走査，ラディアル速度分布を取得しているため，観測セル間での風向・風速変化が顕著となりやすいことにも推定精度の劣化原因として挙げられる．本手法においても，VAD 法同様，乱気流の推定精度に問題を抱えることがわかる．


3.3.3 拡張 VAD 法の性能評価

図 3.5 に拡張 VAD 法による各乱気流モデルの推定結果を示す．竜巻の渦の一部の再現性や，マイクロバーストの追い風領域での誤差軽減，ガストフロントのシャーラインの明瞭化が直感的に見て取れる．ここで，最適化により得られた相関長 $\sigma(r_i)$ に着目する．図 3.6 に各乱気流モデルごとの相関長分布を示す．ここではスケールの違いに注意されたい．一様風の場合，全観測セルでの相関長の平均値は約 500m となっていることが分かる．この相関長値はレンジ分解能で 3 つ分の観測セルを含む大きさであり，式 (2.8) の評価関数で導入，穂 9 ン手法で期待した相関領域の広域化が行われていることが確認できる．一方，乱気流場合，相関長分布は一様風と比べ $\frac{1}{10}$ 以下に小さな値になっていることが分かる．風速ベクトルの変化が


急激な乱気流では，相関領域を縮小する場合の方が推定精度が向上するが，拡張 VAD 法で最適化された相関長は本稿で想定したライダの分解能よりはるかに小さい値に収束している．つまり，ほぼ基準観測セル 1 点のみの観測ラディアル速度のみを用いて風速ベクトル推定を行っていることになる．相関長の最適化範囲の下限をライダ分解に設定したところ，全乱気流モデルで相関長が設定下限値に収束し探索を終了するため風速ベクトル推定に優位な最適化結果が得られなかった．拡張 VAD 法において，相関長が極端に小さくなる原因は評価関数にあり，相関長を縮小する方向に勾配が存在することを確認した．VAD 法に基づく同手法では，評価関数の形状に問題を抱えることが明らかとなった．また，従来の VAD 法や VVP 法と比べ，推定精度の向上は確認されるが，実用化に向けては更なる推定精度の確保が必要となる．




Uniform Distribution model



Tornado model




Microburst model




Gust front model


図 3.3: VAD 法による各乱気流モデルの風速ベクトル推定結果




Uniform Distribution model



Tornado model




Microburst model




Gust front model


図 3.4: VVP 法による各乱気流モデルの風速ベクトル推定結果




Uniform Distribution model



Tornado model



Microburst model



Gust front model

図 3.5: 拡張 VAD 法による各乱気流モデルの風速ベクトル推定結果

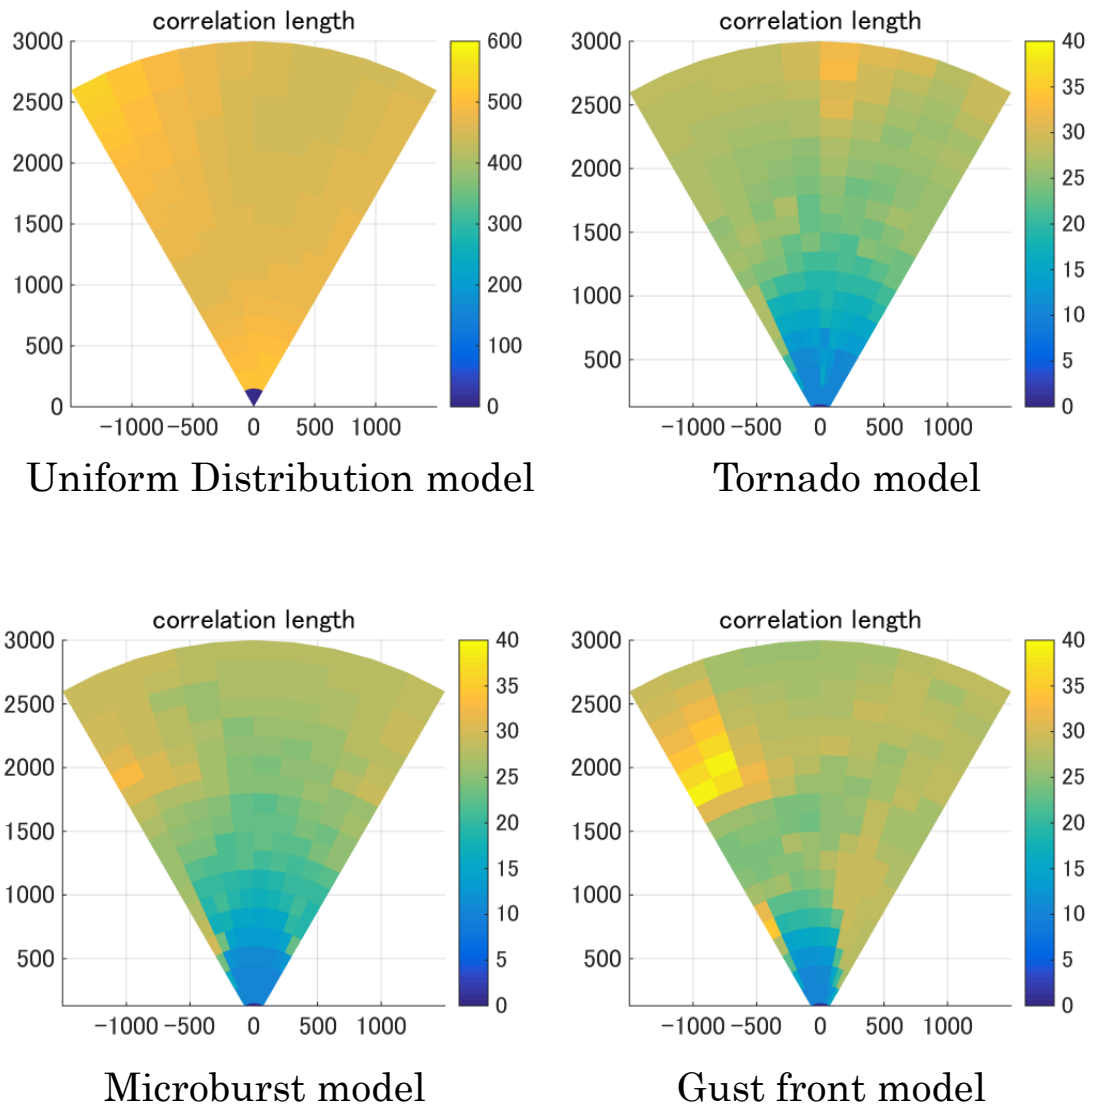


図 3.6: 各乱気流モデルの相関長分布

3.4 推定精度の定量評価

各手法による推定風速ベクトルの推定精度を定量的に評価するため，次式 3.6 に示す正規化平均二乗誤差 (NRMSE: Normalized RootMeanSquareError) を導入する．但し，ここではライダに定常的に乗る計測機器に関するゆらぎや風のゆらぎを考慮しないものとする．

$$\text{NRMSE} = \sqrt{\frac{\sum_{i=1}^N |\mathbf{v}_{\text{true}} - \mathbf{v}_i|^2}{\sum_{i=1}^N |\mathbf{v}_{\text{true}}|^2}} \quad (3.6)$$

但し， \mathbf{v}_{true} は風速ベクトルの真値， \mathbf{v}_i は各観測セルでの推定風速ベクトル， i は観測セルのインデックス， N は観測セル数である．表 3.1 の VAD 法と拡張 VAD 法の NRMSE 値より，拡張 VAD 法による乱気流モデルの推定精度向上が確認できる．このように，局所的な観測領域に一樣風や風速ベクトル場線形変化の仮定した推定法では，原理的に乱気流モデルの推定精度に課題があり，高精度な風速ベクトル推定には別の手法の導入が望まれる．また，これら従来法は局所的な風速ベクトル推定法であるため，観測領域における気流形態の認識には別途手法を適用させる必要がある．そこで次章では，乱気流モデルを記述するパラメータ自体を推定，再構成することで高精度推定法を構築し，同時に乱気流モデルの認識を行う手法について検討する．本稿ではこれをパラメトリック風速ベクトル推定法と呼ぶ．

表 3.1: NRMSE in each wind field model.

	Uniform Wind	Tornado	Microburst	Gust Front
VAD	6.50×10^{-3}	1.36	1.79	2.94
VVP	1.25×10^{-7}	7.45	6.15	3.41
Extended VAD	6.50×10^{-3}	0.761	1.04	0.713

第 4 章

パラメトリック風速ベクトル推定法

本章では、本稿で新たに提案するパラメトリック風速ベクトル推定法を説明する。本手法は、風速ベクトル場を 3 章で定義した数理モデルで表し、モデルのパラメータを同定することで、風向・風速推定する各乱気流モデルの評価関数の勾配を用いた一般的な探索法では、評価関数の多峰性により設定初期値に大きく依存することを明らかにする。この結果を踏まえ、大局的な最適値探索に適した手法として知られている粒子群最適法の適用について検討する。粒子群最適化のネットワーク構成の導入およびラディアル速度分布への前処理により、風速パラメータの推定精度向上を図る。

4.1 勾配法を用いた各乱気流パラメータの推定

非線形最小二乗問題では、反復法を用いた最適パラメータ探索により、最もフィッティングの良いパラメータを決定する。反復法として、最急降下法や準ニュートン法等の評価関数の勾配を用いたアルゴリズムが広く知られている。本稿では一様風、竜巻、マイクロバースト、ガストフロントの 4 つのモデルに対してそれぞれのパラメータを推定し、モデルをフィッティングすることで、乱気流のパターン（乱気流）を認識する。乱気流モデルの観測セル位置 (r_i) におけるパラメータベクトルを $p(r_i) = (p_1, \dots, p_n)$ で表す。但し、 n はパラメータ数であり、乱気流モデルによって異なる。乱気流の形態 k の決定およびそれに対応した各パラメータの最適化は次式の評価関数を用いて行う。

$$\hat{k}(\mathbf{r}_i) = \arg \min_{k(\mathbf{r}_i)} \left(\min_{\mathbf{p}_k(\mathbf{r}_i), \sigma(\mathbf{r}_i)} \frac{\sum_{\mathbf{r}_j \in \Omega_i} e^{-\frac{|\mathbf{r}_i - \mathbf{r}_j|^2}{2\sigma(\mathbf{r}_i)^2}} (v_{\text{est},k}(\mathbf{p}_k(\mathbf{r}_i)) - v_{\text{r,obs}}(\mathbf{r}_j))^2}{\sum_{\mathbf{r}_j \in \Omega_i} e^{-\frac{|\mathbf{r}_i - \mathbf{r}_j|^2}{2\sigma(\mathbf{r}_i)^2}}} \right) \quad (4.1)$$

但し, $v_{\text{est},k}(\mathbf{p}_k(\mathbf{r}_i))$ は乱気流の数理モデル k に依存する推定ラディアル速度, $\sigma(\mathbf{r}_i)$ は相関長, v_{r} は観測ラディアル速度である．ここで, 式 (4.1) の評価関数は信頼領域法を用いて最適化を行う (アルゴリズム詳細は付録を参照)．信頼領域法は最急降下法や準ニュートン法等の直線探索法による反復探索と比べ, 適用範囲が広く数値的に頑健であることが知られている．同手法は反復ごとに評価関数の 2 次近似モデルが妥当であると考えられる領域 (これを信頼領域と呼ぶ) 内において, 2 次近似モデルを最小化する．最小化は次式で行われる．

$$\begin{aligned} \min_{\mathbf{d}} G(\mathbf{d}^{(t)}) &\equiv g(\mathbf{p}^{(t)}) + \nabla g(\mathbf{p}^{(t)})^T \mathbf{d}^{(t)} + \frac{1}{2} \mathbf{d}^{(t)T} \nabla^2 g(\mathbf{p}^{(t)}) \mathbf{d}^{(t)} \\ \text{s.t. } \|\mathbf{d}^{(t)}\| &\leq \Delta^{(t)} \end{aligned} \quad (4.2)$$

但し, t は反復回数, $G(\mathbf{d}^{(t)})$ はモデル関数, $\Delta^{(t)}$ は信頼半径と呼ばれるスカラーである．信頼領域法では, モデル関数の減少量 $\Delta G^{(t)} = G(0) - G(\mathbf{d}^{(t)})$ と評価関数の減少量 $\Delta g^{(t)} = g(\mathbf{p}^{(t)}) - g(\mathbf{p}^{(t)} + \mathbf{d}^{(t)})$ を比較して, 反復点を更新するかと信頼半径の増減を決定し, 最適解を探索する．しかし, 本稿で扱う評価関数では, 多峰性が確認されている．図 4.1 に竜巻モデルの各パラメータ平面を真値周辺で切り出した評価関数形状を示す．竜巻モデルは 4 つのパラメータで記述されるため, 各組み合わせの 6 平面で形状を確認する．図に示す赤点が各平面上での真値パラメータである．特に $x_c - y_c$ 平面, $x_c - r_c$ 平面, $x_c - v_c$ 平面に極小値が複数存在することがわかる．各観測セルごとに推定を行う場合, さらに相関長を加えた 5 次元空間内でパラメータ探索を行うため, より複雑な局所解が存在することが予想される．このように信頼領域法では, 推定精度は初期値に大きく依存することが分かる．同

問題を解決するため，次節で評価関数の形状に依存しないパラメータ探索手法である粒子群最適化 (PSO) の応用を検討する．

4.2 粒子群最適化 (PSO) を用いた乱気流パラメータの推定

粒子群最適化とは，生物の集団行動を模倣した群知能と呼ばれる最適化手法の 1 つである．ここでは，探索パラメータを位置情報として扱い，粒子で模した探索点を更新速度で移動させることで，最適パラメータを探索する．パラメータの探索範囲である n 次元空間に散らばった各粒子は，自身の過去の位置情報に加え，周囲の粒子の過去情報を共有する (アルゴリズムの詳細は付録を参照)．同手法は，評価関数の勾配情報を用いないため，評価関数が多峰性である場合や不連続な場合にも有効な探索法として知られているため，本稿で扱う評価関数においてもパラメータの推定精度を保持することが期待される．ここで，探索空間に散らばった粒子のパラメータベクトルを p とすると，粒子のパラメータの更新式は移動速度ベクトル q を用いて次式で与えられる．

$$\begin{aligned} q_j^{(t+1)} &= w q_j^{(t)} + c_1 r_1 \left(pbest_j^{(t)} - p_j^{(t)} \right) + c_2 r_2 \left(gbest^{(t)} - p_j^{(t)} \right) \\ p_j^{(t+1)} &= p_j^{(t)} + q_j^{(t+1)} \end{aligned} \quad (4.3)$$

但し， j は粒子のインデックス， t は反復数， w は重み， c_1 と c_2 は速度係数， r_1 と r_2 は区間 $[0, 1]$ での一様乱数である． $pbest_j$ はパーソナルベストと呼ばれ j 番目の粒子が現在までに辿った最良のパラメータである． $gbest$ はグローバルベストと呼ばれ，全粒子のパーソナルベストの最良パラメータである．パーソナルベストの更新式は次式で表現される．

$$j_p = \left\{ j \mid g(p_j^{(t+1)}) < g(pbest_j^{(t)}) \right\}$$




図 4.1: 竜巻モデルの各パラメータ平面上での評価関数形状

$$pbest_j^{(t+1)} = \begin{cases} p_j^{(t+1)} & (j \in j_p) \\ p_j^{(t)} & (j \notin j_p) \end{cases} \quad (4.4)$$

但し, $g(\cdot)$ は評価関数である．各粒子のパーソナルベストは自身が辿った過去情報と比較し, 評価関数値が最小のパラメータベクトルを採用する．またグローバルベストの更新式は次式で与えられる．

$$j_g^{(t+1)} = \arg \min_j g(pbest_j^{(t+1)})$$

$$gbest^{(t+1)} = \begin{cases} pbest_{j_g}^{(t+1)} & (g(pbest_{j_g}^{(t+1)}) < g(pbest_{j_g}^{(t)})) \\ pbest_{j_g}^{(t)} & (\text{else}) \end{cases} \quad (4.5)$$

グローバルベストは全パーソナルベスト中で評価関数値が最小のパラメータベクトルである．最適パラメータの探索は, 規定の反復回数や評価関数値を終了条件とする [10][11]．最終的なグローバルベストが本手法を用いた最適探索解となる．粒子群最適化の収束性能を向上させる方法として, 粒子のネットワーク構造の工夫がある [14][15]．図 4.2 に粒子の結合例と探索製の違いについて示す．ここでは, 黒の粒子が基準とする白の粒子と位置情報の共有をしていることを示す．一般的な粒子群最適化アルゴリズムでは図 4.2(a) に示すネットワーク構造が利用されている．同粒子の結合では, 全ての粒子が情報を共有しているため収束が早い．しかし, グローバルベストである粒子が局所解に陥った場合, 抜け出すことが困難であることからパラメータの定精度に劣化を生じる．これは, 各粒子の更新量がグローバルベストとのノルム差に依存しているためで, 更新量の大きい粒子周辺に真の最適解が存在する場合, それを発見できない恐れがあるためである．同問題を解決するために図 4.2(b) に示すようなリング状のネットワーク構造を導入する．同ネットワーク構造では, 結合した粒子からの情報のみを共有するため, 群れ全体での収束速度が低下する一方で, 大局的な探索性能が保持される．このことから, 本稿で扱う多峰性を示す評価関数に対し, パラメータの推定精度向上が期待できる．リング状のネットワーク構造を導入した場合, 更新式 4.3 の上式が次式に変形される．

$$\mathbf{q}_j^{(t+1)} = w\mathbf{q}_j^{(t)} + c_1r_1 \left(\mathbf{pbest}_j^{(t)} - \mathbf{p}_j^{(t)} \right) + c_2r_2 \left(\mathbf{lbest}_l^{(t)} - \mathbf{p}_j^{(t)} \right) \quad (4.6)$$

但し, \mathbf{lbest} は情報を共有する l 番目の局所的な群れにおける最良値である．

さらに, ここではパラメータの探索精度向上のため, PSO アルゴリズムで探索するパラメータの範囲を乱気流の特徴を踏まえて限定する．この前処理は, 風速場が未知の段階で適用させる．まず始めに, 竜巻とマイクロバーストにおけるセグメンテーション処理について説明する．竜巻とマイクロバーストの中心位置では, ラディアル速度に特徴的な分布が現れることから, 大まかな探索範囲の抽出が可能である．中心位置の領域推定法としてシヤーセグメントの抽出がある [16]．シヤーセグメントとは, レンジ方向に抜き出したラディアル速度の正負が変化する距離長である．レンジ方向のシヤーセグメントは次式で与えられる．

$$\mathbf{r}_i(\varphi) \leq \text{shear segment} \leq \mathbf{r}_j(\varphi) \quad (4.7)$$

但し, i, j はレンジ方向のインデックスである．本稿では [14] を基本として, 距離長両端でのラディアル速度差が $|v_r(\mathbf{r}_i) - v_r(\mathbf{r}_j)| \geq 10 \text{ m/s}$ を満たす距離長をシヤーセグメントと定義し, 粒子群最適化の探索範囲に柔軟性を持たせる．図 4.3 に方位角 0° 方向のシヤーセグメントを示す．シヤーセグメントを全方位角方向において抽出し, まとめることで中心座標範囲を限定する．一方, 竜巻モデルのラディアル速度変化はアジマス方向に顕著であることからシヤーセグメントの抽出はアジマス方向に行う．図 4.4 にシヤーセグメントを用いた竜巻とマイクロバーストの中心座標の限定領域を示す．図中黄色で示した領域が, 本処理後の竜巻, マイクロバーストの中心座標の探索範囲である．

次に, ガストフロントを対象としたシヤーライン推定について説明する．ガストフロントは, 一様風, 竜巻, マイクロバーストと比べ, モデルの記述パラメータ数が多いことから, パラメータの推定精度を保持できない場合がある．これは, 粒子群最適化におけるパラメータ推定精度が, 探索初期に初期粒子を散らす際の空間サイズに依存しているためである．探索パラメータが 1 つ増えるごとに探索空間の次

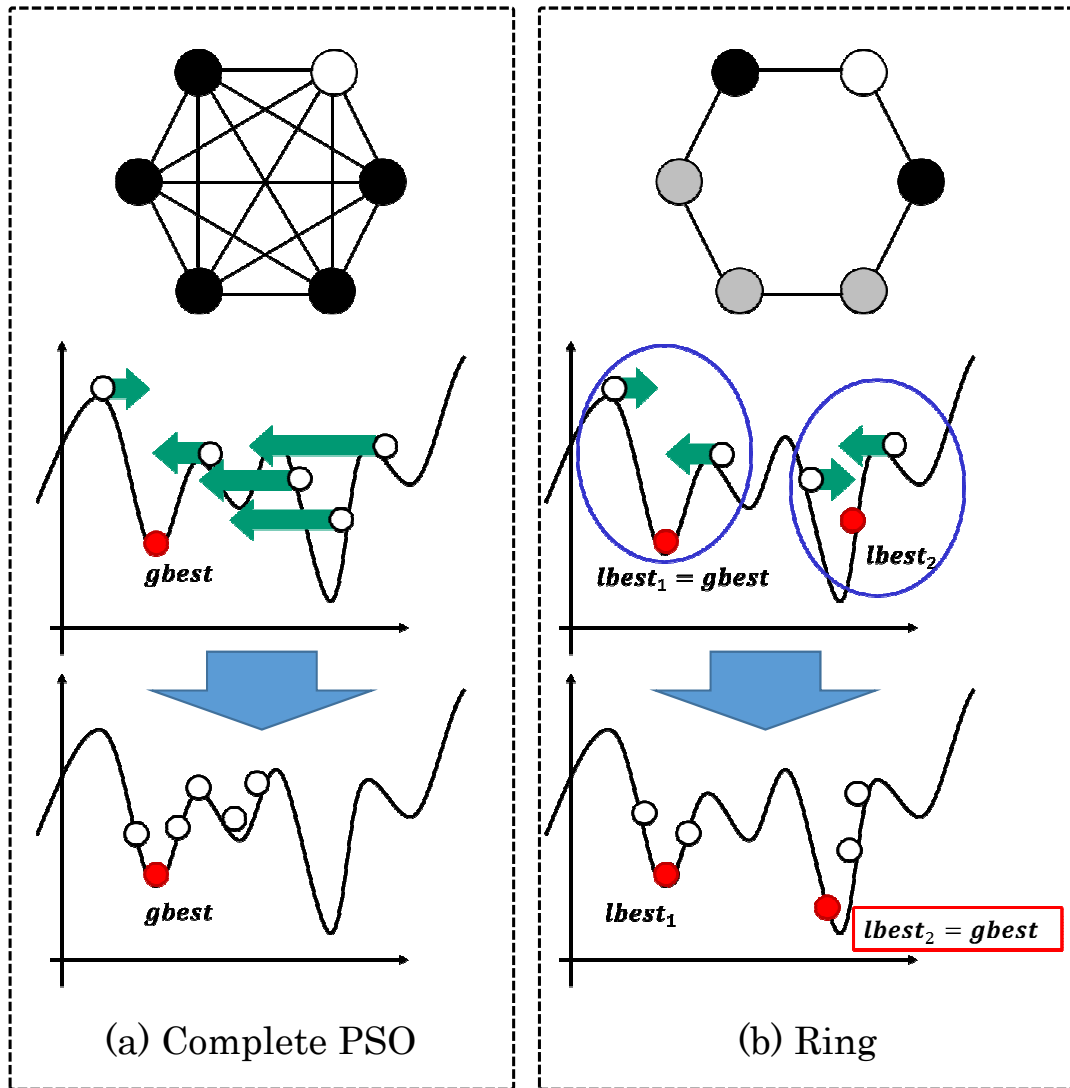


図 4.2: PSO アルゴリズムのネットワーク構造と探索性




図 4.3: マイクロバーストモデルにおける方位角 0° のシヤーセグメント





図 4.4: 中心座標の探索範囲 ((a) 竜巻モデル, (b) マイクロバーストモデル)

元も 1 次元拡大する．同数の粒子を用いる場合，ガストフロントは一樣風と比べ探索空間が 2 次元も異なるため，最も推定精度が低くなる．同問題に対し，観測ラディアル速度分布を用いたシャーラインパラメータの探索範囲の抽出を前処理として行う．シャーラインは円で描かれるため，中心座標および半径の推定が必要である．本稿ではシャーライン推定のために，その近傍と考えられる観測セルの位置情報を利用する．観測セルの選定には，ラディアル速度分布の 2 値化 (大津法) の後に，画像処理技術等で広く利用されるキャニー法 [17][18] を用いたエッジ検出法を適用する (付録参照)．これは，ラディアル速度分布を画像としてとらえた場合，シャーライン近傍の観測セルではラディアル速度が 0m/s になることから，シャーラインが画像上のエッジとして観測されることに帰着する．図 4.5 に，ガストフロントのシャーライン推定結果を示す．抽出される観測セルは，ライダの分解能の依存するため，推定されたシャーラインは真値と比べ誤差を含むことがわかる．シャーラインパラメータの探索範囲の限定は，推定パラメータである $x_{c,est}$, $y_{c,est}$, R_{est} を用いて，それぞれ $[x_{c,est} - 1000, x_{c,est} + 1000]$, $[y_{c,est} - 1000, y_{c,est} + 1000]$, $[0.5 \times R_{est}, 2 \times R_{est}]$ とする．図 4.6 に本手法のフローチャートを示す．


4.3 相関長無限大のパラメトリック推定

前節では，各観測セルごとに風速パラメータおよび相関長を最適化，風速ベクトルを推定する方法について述べた．相関長を導入する利点としては，特に VAD 法や VVP 法といったラディアル速度の変化に着目し風速ベクトルを推定する手法において有効である．しかし，粒子群最適化を用いたパラメトリック推定法では評価関数を各乱気流ごとに用意するため，相関長を導入する手法では，かえって推定に優位な情報までも寄与率を低下させてしまう恐れがある．また，各観測セルごとに風速パラメータを推定した場合，膨大な計算時間や推定パラメータのばらつきが問題となる．同問題に対し，相関長を無限大と考え，全観測セルからの情報を基に各乱気流モデルに対し，1 つの風速パラメータを推定する手法を提案する．モデル決定のための評価関数は次式で表される．


$$\hat{k} = \arg \min_k \left(\min_{\mathbf{p}_k} \sum_{\mathbf{r}_j \in \Omega} (v_{est,k}(\mathbf{p}_k) - v_{r,obs}(\mathbf{r}_j))^2 \right) \quad (4.8)$$




(a) Observed radial velocity



(b) Threshold processing



(c) Edge detection



(d) Shear line estimation

図 4.5: シヤーライン推定結果

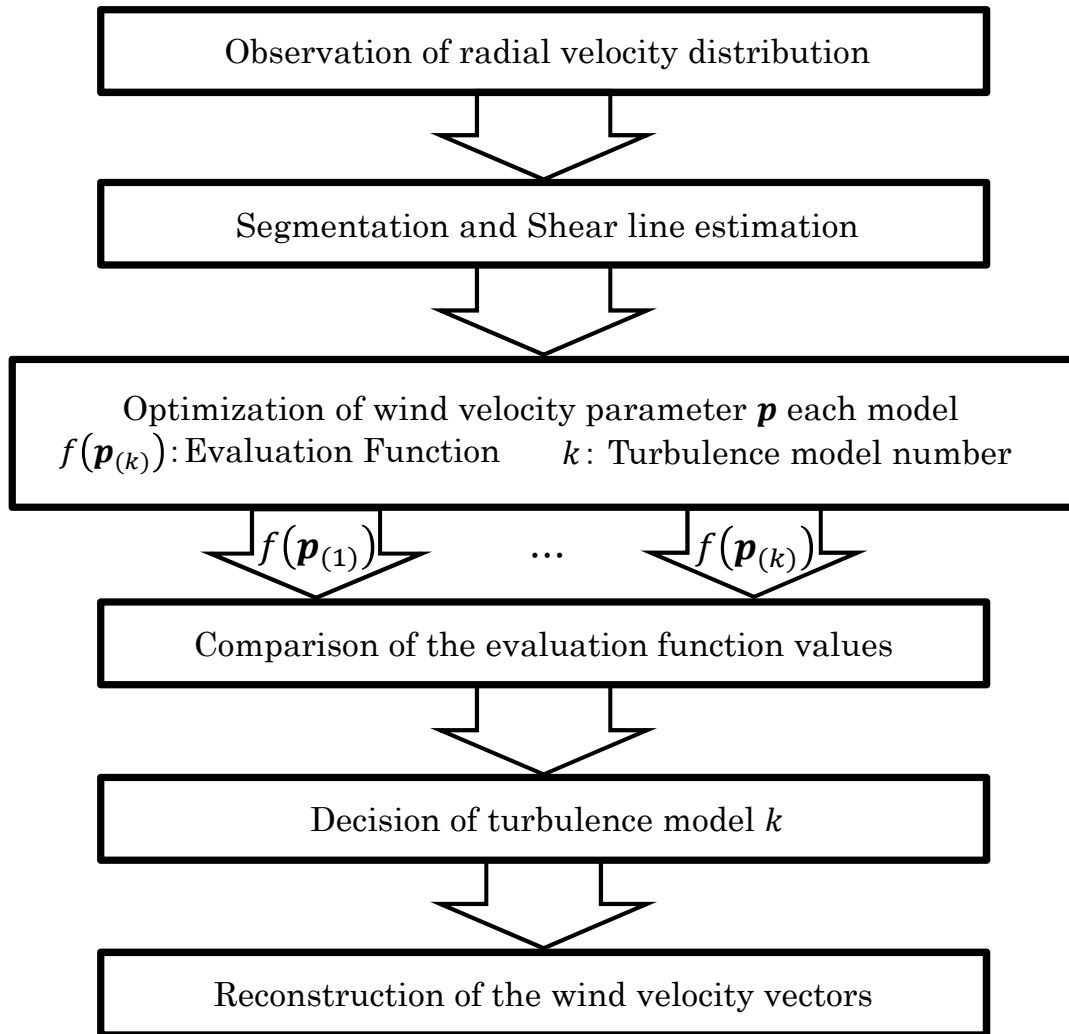


図 4.6: パラメトリック風速ベクトル推定法のフローチャート

但し, Ω は全観測領域である．本手法は, 全ての観測データを用いてパラメータ推定を行うため, 推定精度の向上が期待できる．また, パラメータ推定を行う回数が相関長を導入する手法と比べ計算回数を $1/\text{全観測セル数}$ に軽減できるため, 高速化に繋がる．

第 5 章

提案法の性能評価

本章では，乱気流モデルの推定精度および認識精度を数値計算により評価する．システムモデルと各乱気流の数値モデルおよび真値は第 3 章で述べたとおりである．また風速ベクトルのゆらぎや観測誤差を踏まえて，ゆらぎを与えた場合の推定精度についても評価を行う．

5.1 評価方法

本稿は，風速ベクトルの推定精度と風速場の認識精度についてそれぞれ評価を行う．風速ベクトルの推定精度は，3.6 で定義した正規化平均二乗誤差 (NRMSE) を用いる．風速場の認識は，4.1，4.8 で決定された乱気流モデルと真の乱気流モデルとを比較することで行う．また，ゆらぎをあたえた場合の風速ベクトルの推定精度，風速場認識についても評価する．

ドップラーライダは，機器に定常的に計測ゆらぎと風のゆらぎが加わったものゆらぎとして観測される．本稿が想定するライダでは，計測ゆらぎは風速場とは無相関に， $0.2\text{m/s} \sim 1.0\text{m/s}$ の範囲で観測ラディアル速度にのることが知られている．位置 (r_i) の観測セルにおける計測ゆらぎののったラディアル速度は次式で与えられる．

$$v_r(r_i) = v_{r(\text{true})} + \Delta v_r \quad (5.1)$$

但し, $v_{r(\text{true})}$ は観測ラディアル速度の真値, Δv_r はゆらぎである．ゆらぎ確率密度関数は $f(\Delta v_r) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{\Delta v_r^2}{2\sigma^2}}$ で与えられるガウス分布で表現される．

次に, 風速ベクトルのゆらぎを付加した場合について評価する．風ベクトルのゆらぎは, 自然現象 (そよ風, 小川のせせらぎ, 細胞活動等) に多く見られる $\frac{1}{f^\beta}$ ゆらぎモデルを用いて模擬する．同ゆらぎは, 完全にランダムな計測ゆらぎとは異なり, ゆらぎのパワースペクトルが周波数に反比例することに由来し, 次式で表現される．

$$S(f) \propto \frac{1}{f^\beta} \quad (5.2)$$

但し, $S(f)$ はゆらぎのパワースペクトル, f は周波数, β はゆらぎのカラーに関する係数である．自然界のゆらぎは大きく分けて, $\beta = 0$ のホワイトノイズ, $\beta = 1$ のピンクノイズ, $\beta = 2$ のブラウニアンノイズの 3 つが存在する [19]．本稿は, そよ風が $\beta = 1$ の周波数特性を持つことを踏まえ, 風速ベクトルのゆらぎを考える．風速ベクトルのゆらぎは上記のゆらぎを, 風速場記述パラメータに付加することで次式で作成する．

$$\hat{p}_k(r_i) = p_k + \Delta p_k \quad (5.3)$$

但し, \hat{p}_k は真値風速ベクトル場作成のための風速パラメータ, p_k は基準風速パラメータ, Δp_k は風速パラメータのゆらぎである．図 5.1 に, 竜巻のパラメータに $\frac{1}{f}$ ゆらぎを付加した場合の風速ベクトル場を示す．図 5.1 左は, 渦中心のパラメータの 1 つである x_c のゆらぎ分布を, 横軸に観測セル数を取り示したものである．各乱気流の風速ベクトル場は, 全てのパラメータに対し同様のゆらぎを与え作成する．

5.2 風速ベクトルの推定精度

図 5.2 に信頼領域法を用いた各乱気流の推定結果を示す．各モデルの探索開始の初期値は, 一様風モデル $(v_h, \theta) = (0\text{m/s}, 0^\circ)$, 竜巻モデル $(x_c, y_c, r_c, v_c) = (150\text{m}, 1650\text{m}, 150\text{m}, 10\text{m/s})$, マイクロバーストモデル $(x_c, y_c, r_c, v_c) = (150\text{m}, 1650\text{m}, 150\text{m}, 10\text{m/s})$, ガストフロントモデル $(x_c, y_c, R, v_1, v_2) = (-1350\text{m}, 3150\text{m}, 2150\text{m}, 10\text{m/s}, 160\text{m})$ とする．また相関長 σ の初期値は, 全てのモデルで 600m とする．表 5.1 の結果が




図 5.1: Tornado with parameter fluctuations.

ら分かるように，一様風モデルの推定は良好な結果が得られている．一方乱気流モデルでは，推定結果と真値とに大きな推定誤差を含む風速ベクトル分布を示している．これは 3.1 節で先述した通り，多峰性を示す評価関数の最適化において，局所解に陥ったためと考えられる．また，各乱気流モデルの探索の初期値は，真値に対して 1 分解能程度のずれで非常に近い値に設定している一方で，推定精度に著しい劣化が生じている．ライダの観測精度を考慮すると，これ以上の精度で初期値を抽出することは困難であることから，勾配法を用いた乱気流パラメータの推定に限界があることが確認された．

図 5.3 に相関長を導入し，最適化には粒子群最適化を用いた場合の推定結果を示す．粒子数は 500 個，最大反復回数は 200 回とする．式 (4.3) の各係数は， $w = 0.729$ ， $c_1 = c_2 = 1.4955$ とする．同係数設定は Construction Method で示される安定解析に基づき，パラメータを弱い安定領域に設定したものである．但し r は区間 $[0,1]$ での一様乱数である．反復回数以外の PSO アルゴリズム終了条件として，正規化半径内に規定の粒子数が集まった場合もパラメータが十分収束したと見なし更新を終了する．正規化半径は次式で定義される．

$$R_n = \sqrt{\sum_{i=1}^n \left(\frac{gbest_i - pbest_i}{\sup \{p_i\}} \right)^2} \quad (5.4)$$

但し, i はパラメータのインデックス, $\sup \{p_i\}$ はパラメータ探索範囲の最大値である. 各モデルの正規化半径は, 一様風モデル, 竜巻モデル, マイクロバーストモデル, ガストフロントでそれぞれ 0.5, 0.8, 0.8, 0.8 とする. 粒子群最適化アルゴリズムの終了規定値は全体の粒子の 80% とする. また各モデルのパラメータ探索範囲は, 一様風モデルが $[0 \leq v_h \leq 50, -180^\circ \leq \theta \leq 180^\circ]$, 竜巻とマイクロバーストモデルが $[x_{\min} \leq x_c \leq x_{\max}, y_{\min} \leq y_c \leq y_{\max}, 0 \leq r_c \leq 400, 0 \leq v_c \leq 50]$, ガストフロントモデルが $[-3000 \leq x_c \leq 3000, -1000 \leq y_c \leq 5000, 1000 \leq R \leq 3000, 0 \leq v_1 \leq 50, 100 \leq v_2 \leq 200]$ と設定した. 但し, 竜巻モデルとマイクロバーストモデルの $x_{\min}, x_{\max}, y_{\min}, y_{\max}$ は前章で述べた観測ラディアル速度より限定される探索範囲の最大・最小値である. 相関長は拡張 VAD 法の乱気流モデルの推定で問題となった様に, 過敏に縮小しないよう探索範囲は $450 \leq \sigma \leq 1000$ とする. 表 5.1 に信頼領域法と粒子群最適化の NRMSE を示す. 表 5.1 の結果から, 従来の VAD 法に基づく手法や導関数を用いたパラメータ推定では風速ベクトルの高精度推定が難しかった竜巻モデルとマイクロバーストの両モデルで推定精度が改善され, モデルの再現性向上が風速ベクトル分布から確認できる. 一様風モデルでは風向に若干の推定誤差が生じていることが分かる. これは粒子群最適化アルゴリズムにより各観測セルごとに得られる最適パラメータが, 乱数に依存するためだと考えられる. 同手法では n 次元空間に粒子を散らばす際, 初期値に一様乱数を用いる. また, 各粒子の更新式においても乱数が影響する項が 2 つ含まれるため, 探索範囲が同じでも異なる最適解を最終的に出力する場合が存在する. 乱数によるばらつきを評価するため, 本稿では 50 回の平均値を表 5.1 の結果としている. ガストフロントモデルの推定風速ベクトルは, 他の乱気流モデルと比べ推定精度が劣る. この要因として考えられるのは, パラメータ数が最も多い乱気流モデルである点と, そのパラメータ探索範囲が広い点である. 探索パラメータ数を n とした場合, パラメータが 1 つ増えるごとに, 粒子群最適化のパラメータ探索範囲は $n + 1$ 次元の空間へと拡張する. 本稿では乱気流モデルによらず, 粒子群最適化で最適解を探索する粒子

数を 500 個としている．そのため，一様風モデルにおいては探索範囲に対し粒子密度が高い状態で探索を開始できる一方で，ガストフロントでは粒子密度が低い状態での探索開始となる．各観測セルごとに最適パラメータの推定を行う本手法においては，計算時間が約 6000 秒と膨大な計算時間を要している (CPU: Intel Xeon(R) E5-1620(3.6GHz) 使用)．竜巻やマイクロバーストのように，発生から消滅までの時間が数分から数十分の比較的短い時間スケールでの現象の推定を行うためには，計算処理の高速化も求められる．

図 5.4 は，相関長を無限とした粒子群最適化による各乱気流の推定結果である．粒子群最適化の各パラメータは，上記の相関長を導入した手法と同様に設定する．ここでは，相関長を導入したパラメトリック推定法と同様に，竜巻とマイクロバーストにセグメンテーション処理を，ガストフロントに対してシャーライン推定をそれぞれ前処理として施す．相関長を無限大としたパラメトリック推定では，各乱気流モデルにおけるパラメータのばらつきが無くなったことで，推定精度が向上することが視覚的にわかる．推定された風速パラメータを表 5.2，表 5.3，表 5.4，表 5.5 にまとめた．いずれの乱気流モデルにおいても，高精度にパラメータ推定が行われたことが確認できる．これは，全観測セルの情報を利用することにより，推定に寄与するデータ数を十分に確保できたことが要因だと考えられる．表 5.1 から，風速ベクトルの推定精度の大きな向上が確認できる．特に，竜巻，マイクロバースト，ガストフロントの乱気流モデルにおいて，推定誤差が約 5% ~ 10% 程度となり，推定パラメータ数の最も少ない一様風とほぼ同スケールまで低減された．また，観測セルごとに風速ベクトルを推定するパラメトリック推定とは異なり，一意の風速パラメータを用いて風速ベクトルを再構成するため，計算時間においても約 240 秒程に短縮され，約 $\frac{1}{25}$ にまで高速化を実現した (CPU: Intel Xeon(R) E5-1620(3.6GHz) 使用)．

次に，計測ゆらぎをあたえた場合の評価を行う．標準偏差 $\sigma = 0.2\text{m/s}$ のゆらぎを付加した場合のラディアル速度分布にを図 5.5 に示す．図 5.6 はゆらぎの標準偏差を変化させたときの推定精度を表す．図 5.6 より，従来法では，特に一様風やガストフロントにおいてゆらぎの増加に伴う推定精度の劣化が生じる一方で，パラメトリック推定法ではゆらぎに対しロバスト性を保持することが確認できる．提

表 5.1: NRMSE in each wind field model.

	Uniform Distribution	Tornado	Microburst	Gust Front
Trust Region	0.224	1.38	2.17	0.793
PSO	0.205	0.468	0.441	0.801
PSO($\sigma = \infty$)	0.052	0.053	0.039	0.099

表 5.2: Wind parameters of uniform distribution model.

	v_h [m/s]	θ°
True	10	135
Estimation	9.52	135

表 5.3: Wind parameters of tornado model.


	x_c [m]	y_c [m]	r_c [m]	v_c [m/s]
True	0	1500	200	20
Estimation	-1.78	1489	199	20.1

表 5.4: Wind parameters of microburst model.


	x_c [m]	y_c [m]	r_c [m]	v_c [m/s]
True	0	1500	200	20
Estimation	3.17	1495	212	19.2

表 5.5: Wind parameters of gust front model.


	x_c [m]	y_c [m]	R [m]	v [m/s]	σ [m]
True	-1500	3000	2000	5	140
Estimation	-1.63	3126	4.94	133	151




Uniform Distribution model



Tornado model




Microburst model




Gust front model


図 5.2: 信頼領域法を用いた各乱気流モデルの風速ベクトル推定結果




Uniform Distribution model



Tornado model




Microburst model




Gust front model


図 5.3: 粒子群最適化を用いた各乱気流モデルの風速ベクトル推定結果




Uniform Distribution model



Tornado model



Microburst model



Gust front model

図 5.4: 相関長無限大の粒子群最適化を用いた各乱気流モデルの風速ベクトル推定結果

表 5.6: NRMSE in each wind field model.

	Uniform Distribution	Tornado	Microburst	Gust Front
VAD	0.654	1.95	1.99	1.67
VVO	2.51	6.94	6.34	4.25
Extended VAD	0.493	1.57	1.34	1.04
PSO	0.255	1.21	0.729	0.837
PSO($\sigma = \infty$)	0.108	0.418	0.471	0.425

案法における風速ベクトル推定では，先述の通り，相関長を導入しない場合において，乱気流モデルにおいて高精度推定が行われることがわかる．これは，相関長を除いたことで，粒子群最適化の探索空間が縮小し，風速パラメータの推定精度が向上したためだと考えられる．また，乱気流パラメータを一意に定める相関長無限大の推定法では，ゆらぎによるばらつきが平均効果により低減されるため，最も推定精度が高い結果となった．

次に， $\frac{1}{f}$ 風速ベクトルのゆらぎを $\frac{1}{f}$ モデルを用いて付加した場合の推定結果について表 5.6 に示す．同ゆらぎは，ライダにのる計測ゆらぎと比べゆらぎ量が大きいいため，ラディアル速度分布の形状に崩れが生じる．そのため風速ベクトルの推定精度は，全ての手法において劣化することがわかる．一方，相関長無限大の粒子群最適化を用いた推定では，他の手法と比べ推定精度の劣化が低減されていることが確認できる．

5.3 気流モデルの認識精度

次に信頼領域法と粒子群最適化を用いて，未知の乱気流を 4 モデルに分類した時の認識精度を示す．認識には評価関数値を利用し，4 モデル中最小のものをその観測セルに吹く気流モデルとして採用する．図 5.7 と図 5.8 に両手法の各観測セルにおける気流モデルの認識結果を示す．ここではゆらぎを考慮しないものとする．カラーバーは，濃青：一様風，水色：竜巻，黄緑：マイクロバースト，黄色：ガストフロントにそれぞれ対応する．表 5.7 は信頼領域法を用いた気流モデルの認識率

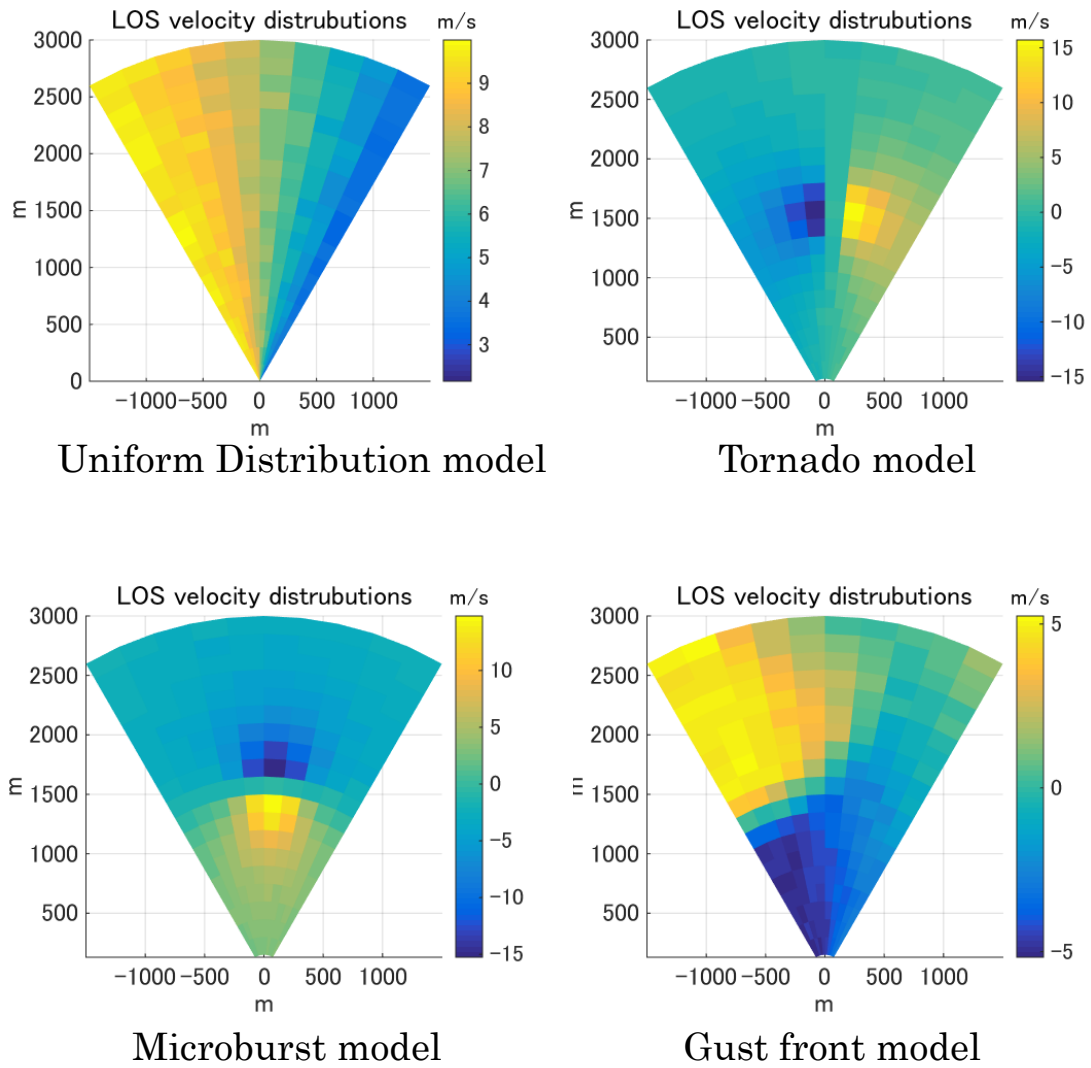


図 5.5: 計測ゆらぎ ($\sigma = 0.2\text{m/s}$) を乗せた場合の各モデルにおけるラディアル速度分布

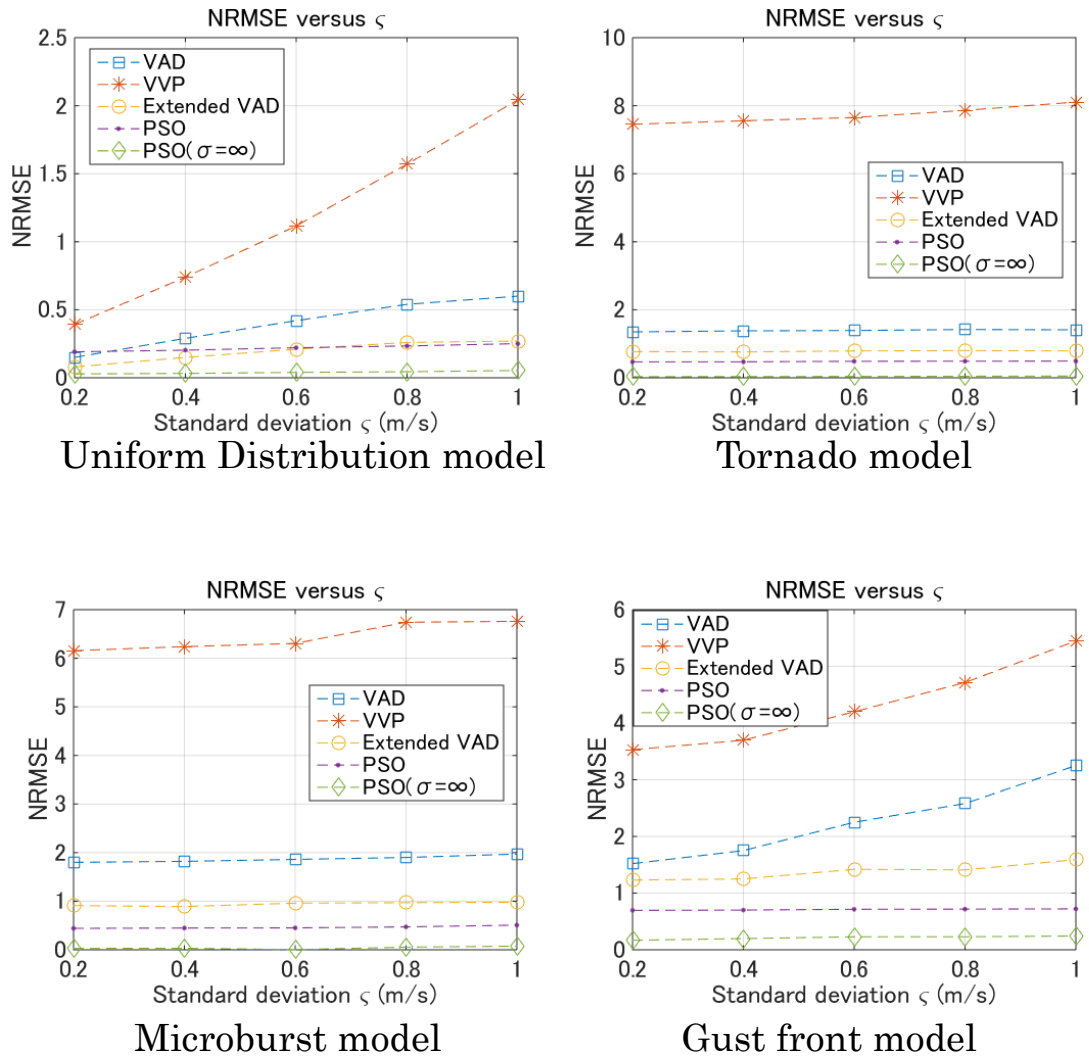


図 5.6: ゆらぎ量変化による推定精度の遷移

を表す．認識率は正しく認識した観測セル数を全観測セルで割ったものである．信頼領域法では一様風で高い認識精度を示すことが分かる．しかし，竜巻やマイクロバーストといった乱気流モデルにおいては，一様風やガストフロントと誤認識する確率が高く，気流モデルの認識が困難であることが確認される．これは，竜巻，マイクロバーストの両モデルのパラメータ推定精度が低いためである．信頼領域法では，評価関数の多峰性により局所解に陥りやすい．認識には評価関数値を使用するため，未知の気流モデルに対し，真の気流モデルパラメータの推定精度が著しく低い場合には，認識率も大きく影響を受ける．その結果，推定相関長が小さい場合は一様風に，大きな場合はフィッティングに幅のあるガストフロントに誤認識されたと考えられる．表 5.8 は粒子群最適化を用いた気流モデルの認識率を表す．粒子群最適化においては，一様風とガストフロントで高い認識精度を保持し，また竜巻とマイクロバーストでも信頼領域法と比べ認識精度の向上を示している．但し，竜巻・マイクロバーストモデルでは，発生中心座標より離れた遠方の観測セルにおいて，ガストフロントモデルと誤認識する観測セルが多々見られる．両モデルではランキン渦モデルを用いたモデル化を採用しているため，風速が減衰する現象の端ではラディアル速度が微小にしか観測されない．つまり，気流モデル認識に優位となる特徴的な観測量が得られず，誤認識に繋がったと考えられる．ガストフロントとして誤認識された観測セルの推定風速を確認したところ，風速 v_1 が小さく中心座標がライダ位置と比べ遠方に存在するガストフロントモデルへの収束が多数確認された．ガストフロントモデルへの収束に陥った原因は，パラメータ数が多くフィッティングの幅の広いためと考えられる．一方，表 5.9 に相関長無限大の粒子群最適化を用いた認識結果を示す．ここでは，各観測セルごとの認識率ではなく，全体の認識結果を意味する（風速パラメータを一意に定める手法のため）．全観測データを用いて乱気流モデル k を決定するため，高い認識結果が得られることがわかる．

表 5.7: Recognition rate in each wind field model with Trust Region.


True wind field	Uniform Distribution	Tornado	Microburst	Gust Front
Uniform Distribution	100%	0%	0%	0%
Tornado	35.9%	1.73%	2.16%	60.2%
Microburst	41.1%	3.03%	12.5%	43.2%
Gust Front	21.6%	4.32%	1.73%	72.3%

表 5.8: Recognition rate in each wind field model with PSO.


True wind field	Uniform Distribution	Tornado	Microburst	Gust Front
Uniform Distribution	96.5%	0%	0%	3.46%
Tornado	0%	55.0%	0%	45.0%
Microburst	0.865%	0%	61.4%	37.7%
Gust Front	0%	0%	0%	100%

表 5.9: Recognition rate in each wind field model with PSO($\sigma = \infty$).


True wind field	Uniform Distribution	Tornado	Microburst	Gust Front
Uniform Distribution	100%	0%	0%	0%
Tornado	0%	100%	0%	0%
Microburst	0.865%	0%	100%	0%
Gust Front	0%	0%	0%	100%




Recognition results of
Uniform Distribution model



Recognition results of
Tornado model




Recognition results of
Microburst model




Recognition results of Gust
front model

図 5.7: 信頼領域法を用いた気流モデルの認識結果
(濃青：一様風，水色：竜巻，黄緑：マイクロバースト，黄色：ガストフロント)




Recognition results of
Uniform Distribution model



Recognition results of
Tornado model



Recognition results of
Microburst model



Recognition results of Gust
front model

図 5.8: 粒子群最適化 (相関長導入) を用いた気流モデルの認識結果
(濃青：一様風，水色：竜巻，黄緑：マイクロバースト，黄色：ガストフロント)

第 6 章

結論

本稿では，乱気流数理モデルのパラメータ推定による，風速ベクトル推定法および乱気流の自動認識法を提案した．パラメータの探索法として，評価関数の勾配を用いる信頼領域法および粒子群最適化法を取り上げ，評価関数の特性から本推定問題では粒子群最適化法が優れた性能を示すことを明らかにした．粒子群最適化法は，評価関数の形状に依存しないで最適パラメータの探索が可能である．ここでは，推定精度のさらなる向上を狙い，粒子群最適化へのネットワーク構造の導入および，観測量を利用した探索範囲を制限する手法を導入した．

推定精度の評価値として NRMSE を定義し，数値計算による提案法の効果を定量的に評価した．その結果，従来法 (VAD 法，VVP 法，拡張 VAD 法) では推定精度の保持が困難であった竜巻，マイクロバーストの乱気流モデルにおいて，提案法では NRMSE を 1 桁程度の誤差にまで低減し，推定精度向上を実現した．また，計測誤差や風速ベクトルのゆらぎを加えた場合において，提案法の高いロバスト性を確認した．

今後の課題として，計算時間の短縮と更なる乱気流パラメータの推定精度向上が挙げらる．

謝辞

本研究を遂行するにあたり，多大なるご指導を賜りました電子制御システムコース桐本哲郎教授に心から御礼申し上げます．学会発表や論文作成など，丁寧かつ熱心なご指導を頂きました木寺正平准教授，尚方助教授に深く感謝致します．また，共同研究としてご指導頂いた三菱電機情報総合研究所の鈴木信弘様，酒巻洋様に感謝致します．そして，事務手続きに関し，日ごろから支えて頂きました猪原園子秘書に感謝の意を表します．最後に，研究に限らず互いに励ましあい，研究室生活に刺激を与えてくださった桐本研究室の皆様に感謝し，本論文の結びとさせていただきます．

第 7 章

付録

.0.1 信頼領域法

信頼領域法の詳細について説明する．本手法では，この 2 次モデルへの近似が妥当である領域を変化させ，その領域ごとに最小化を行う．同領域を信頼領域と呼ぶ．図 1 に近似度による信頼領域の変化を示す．黒線が評価関数，赤線が近似された 2 次モデル，青で示す領域が信頼領域である．(a) は評価関数を 2 次モデルへの近似度が低く信頼領域が狭い．一方 (b) は，近似度が高く信頼領域が広い．最適解の探索は式 (4.2) を図 1 で示した信頼領域内において，部分問題を解くことにより算出する．この解を $d^{(t)}$ としたとき，近似度 $r^{(t)}$ は次式で与えられる．

$$r^{(t)} = \frac{g(p^{(t)}) - g(p^{(t)} + d^{(t)})}{G(0) - G(d^{(t)})} \quad (1)$$

信頼領域法の各ステップは以下の通りである．

Step 1.

定数 $0 < \mu_1 < \mu_2 < 1$, $0 < \gamma_1 < 1 < \gamma_2$ を設定する．また初期値 $p^{(0)} \in R^n$ と初期信頼領域 $\triangle^{(0)}$ を与え， $k = 0$ とする．

Step 2.

部分的最小化問題である式 (4.2) を解き $d^{(t)}$ を算出する．算出解 $d^{(t)}$ の大きさ等による終了条件を満たす場合には探索を終了する．

Step 3.

近似度 $r^{(t)}$ を計算する． $r^{(t)} \geq \mu_1$ を満たす場合には， $p^{(t+1)} = p^{(t)} + d^{(t)}$ と解の更新を行う．一方， $r^{(t)} < \mu_1$ を満たす場合には，解の更新は行わず $p^{(t+1)} = p^{(t)}$ とする．

Step 4.

近似度が $r^{(t)} \geq \mu_2$ を満たす場合には，信頼領域は $\Delta^{(t+1)} = \gamma_2 \Delta^{(t)}$ の様に拡張される． $\mu_1 \leq r^{(t)} < \mu_2$ を満たす場合には，信頼領域は $\Delta^{(t+1)} = \Delta^{(t)}$ と領域を保持する． $r^{(t)} < \mu_2$ を満たす場合には，信頼領域を $\Delta^{(t+1)} = \gamma_2 \Delta^{(t)}$ で縮小する．反復回数を $t = t + 1$ とし Step 2. へ戻り，信頼領域の拡大・縮小を繰り返しながら最適解の探索を継続する．

.0.2 粒子群最適化 (PSO)

粒子群最適化 (PSO) の詳細について説明する．本手法は n 次元探索空間に散らばらせた粒子群を用いて，最適解を探索するアルゴリズムである．各粒子は位置ベクトルに見立てたパラメータベクトルと，移動ベクトルを持つ探索点である．粒子群は互いの位置情報を基に，位置と速度を更新し最適解を探索する．図 2 に粒子 j における位置ベクトルの更新を示す．粒子群最適化の各ステップは以下の通りである．

Step 1.

粒子数 m ，最大反復回数 t_{max} ，収束判定を行う正規化半径 R_n を設定し，反復回数を $t = 0$ する．

Step 2.

各粒子の初期位置 $p^{(0)}$ と初期速度 $v^{(0)}$ を乱数により探索空間領域内にランダムで与える．

Step 3.

各粒子の位置ベクトルと速度ベクトルを式 (4.3) を用いて更新する．

Step 4.

各粒子のパーソナルベスト $pbest$ とグローバルベスト $gbest$ を , 式 (4.4) および (4.5) を用いて更新する .

Step 5.

反復回数を $t = t + 1$ とし , Step 3. へ戻る . 設定した終了条件を満たすまで粒子の位置ベクトルを更新し続け , 最適解を探索する . 探索終了時の $gbest$ を最適解とする .




図 1: 2 次モデル近似における信頼領域の変化

.0.3 キャニー法

キャニー法によるエッジ検出法の詳細について述べる . 本手法は , Gaussian フィルタと Sobel フィルタを組み合わせたエッジ検出法で , 画像処理分野で現在も広く利用されている . エッジ抽出は , 画像の平滑化 , Sobel 法によるエッジ強度および方向の算出 , 非最大値抑制 (画像の細線化) , ヒステリシス閾処理の 4 ステップに分かれる . 各ステップは以下の通りである .

Step 1.

Gaussian フィルタ $g(x, y)$ を用いた画像の平滑化を行い , ノイズの影響を低減




図 2: 粒子の位置ベクトル更新過程

する．平滑化後の画像は $S = I * g(x, y)$ であたえられる．但し， I は入力画像， $g(x, y) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{x^2+y^2}{2\sigma^2}}$ である．

Step 2.

Sobel フィルタによる各方向の微分を算出する．画像の微分値は $\nabla S = (\nabla g) * I$ で表現される．但し $\nabla g = \left[\frac{\partial g}{\partial x}, \frac{\partial g}{\partial y} \right]^T$ である．ここでエッジ勾配の大きさ，方向はそれぞれ $\sqrt{S_x^2 + S_y^2}$ ， $\theta = \tan^{-1} \frac{S_y}{S_x}$ で求められる．

Step 3.

非最大値抑制では，次式を用いて画素がローカルに最大であるか判定する．

$$M(x, y) = \begin{cases} |\nabla S|(x, y) & (|\nabla S|(x, y) > |\nabla S|(x', y') \cap |\nabla S|(x, y) > |\nabla S|(x'', y'')) \\ 0 & (\text{otherwise}) \end{cases}$$

但し， $M(x, y)$ は細線化後の画像， (x', y') および (x'', y'') は (x, y) を基準とした勾配方向の内挿画素位置である．これにより，Gaussian フィルタを適用させたことで太くなったエッジを細線化させる．

Step 4.


ヒステリシス閾処理では，高低の 2 つの閾値を使用し最終的なエッジ検出を行う．細線化後の画像 $M(x, y)$ において，高閾値以上の画素ではエッジ有り

として，低閾値未満の画素ではエッジ無としてそれぞれ判定する．また高閾値未満，低閾値以上の画素においては，近傍画素（一般には 8 方向）にエッジが存在する場合にのみエッジ有として判定する．

図 3 に各ステップにおけるエッジ抽出例を示す．



(a) Input image



(b) Differential image (S_x)



(c) Gradient image



(d) Non-maximum Suppression



(e) Hysteresis Threshold

図 3: キャニー法によるエッジ抽出例

参考文献

- [1] US Department of Transportation, FAA, "Terminal Doppler Weather Radar," *Specification*, FAA-E-2806b, Nov, 1989
- [2] Evans, J and Turnbull, D, "Development of an automated windshear detection system using Doppler weather radar," *PROCEEDINGS OF THE IEEE*, vol.77, no. 11, Nov, 1989.
- [3] 浜津亨助, 畑清之, 石原正仁, 橋本浩之, 深尾昌一郎, "低層ウィンドシヤー検出用ドップラーレーダの開発," *電子情報通信学会論文誌*, vol6, J83-B, pp. 894-909, Jun. 2000.
- [4] Fujita, T. T. and F. Caracena, "An Analysis of Three Weather-Related Aircraft Accidents," *Bulletin American Meteorological Society*, Vol. 58, pp.1164-1181, Nov. 1977.
- [5] Browning, K. A. and Wexler, R., "The Determination of Kinematic Properties of a Wind Field Using Doppler Radar," *J. Appl. Meteor, Climatol.* 7, pp. 105-113, Feb. 1968.
- [6] 深尾昌一郎, 浜津亨助 "気象と大気のレーダーリモートセンシング [改定 第2版]", 京都大学学術出版会, 2009
- [7] T. Masuo, S. Kidera, T. Kirimoto, H. Sakamaki and N. Suzuki, "Accurate Wind Velocity Estimation Method with Single Doppler LIDAR Model", International Conference on Space, Aeronautical and Navigation Electronics (IC-SANE), Oct. 2014.

- [8] Waldteufel, P. and H. Corbin, "On the Analysis of Single Doppler Radar Data," *J.Appl.Meteor*, Climatol. 18, pp.532-542, Feb. 1979.
- [9] A. Sathe, J. Mann, J. Gottschall, M. S. Courtney, "Can Wind Lidars Measure Turbulence?", *Journal of Atmospheric and Oceanic Technology*, Vol.28, pp.853-868, Jul, 2011.
- [10] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," *IEEE International Conference on Neural Networks*, vol.4, pp. 1942-1948, 1995.
- [11] J. Kennedy, "The particle swarm: Social adaptation of knowledge," *IEEE International Conference on Evolutionary Computation*, pp. 303-308, 1997.
- [12] C. A. Wan and C. C. Chang, "Measurement of the velocity field in a simulated tornado-like vortex using a three-dimensional velocity probe," *Journal of Atmospheric Science*, vol.29, pp.116-127, Jun. 1972.
- [13] M. R. Hjelmfelt, "Structure and life circle of microburst outflows observed in Colorado," *J.Appl.Meteor*, vol.27, pp.900-927, Aug. 1988.
- [14] J. Kennedy and R. Eberhart, "Population structure and particle swarm performance," *IEEE Congress on Evolutionary Computation*, vol.2, pp.1671-1676, 2002.
- [15] K. Kawamura and T. Saito, "The neighborhood of canonical deterministic PSO," *Proc. IEEE Congr. Evol. Comput.*, pp.1937-1944, Jul, 2011.
- [16] 浜津亨助, 畑清之, 石原正仁, 橋本浩之, 深尾昌一郎, "ドップラーレーダを用いた低層ウィンドシャー検出用アルゴリズムの開発," *電子情報通信学会論文誌*, vol.7, J83-B, pp. 1067-1080, Jun. 2000.
- [17] J. Canny, "A computational approach to edge detection," *IEEE Trans. Pattern Anal. Machine Intell.*, vol. 8, no. 6, pp. 679-698, 1987.

参考文献

- [18] Geng Hao, Luo Min, Hu Feng, "Improved Self-Adaptive Edge Detection Method Based on Canny," Intelligent Human-Machine Systems and Cybernetics (IHMSC), 2013 5th International Conference, Vol.2, pp.527-530, 2013.
- [19] 武者利光, "ゆらぎの世界 自然界の $\frac{1}{f}$ ゆらぎの不思議," 講談社, 1980.